

차세대 기계학습 기술

서울대학교 | 장병탁*

1. 서론

경험으로부터 학습할 수 있는 능력은 사람을 포함한 지능적인 시스템의 가장 근본적인 특성 중의 하나이다. 기계학습(Machine Learning)은 “환경과의 상호작용에 기반한 경험적인 데이터로부터 스스로 성능을 향상시키는 시스템을 연구하는 과학과 기술”로 정의된다. 이 정의에서 주목해야 할 것은 학습 시스템이 “환경”, “데이터”, “성능”의 요소를 가지고 있다는 것이다. “환경”은 학습 시스템이 독립적으로 존재하지 않고 상호작용하는 대상이 있다는 것이며 상호작용의 방법에 따라서 경험하는 “데이터”의 형태가 다르다. 이것은 보통의 컴퓨터 프로그램이 이미 프로그램이 작성될 때 모든 가능한 입력을 고려하여 그 경우만을 다루도록 설계되는 것과 구별된다. 학습 시스템은 또한 문제해결을 수행하며 이 수행의 “성능”이 시간이 감에 따라 향상된다. 예를 들어, 사용자가 전자 메일을 사용하는 패턴을 분석하여 자동으로 스팸 메일을 차단해 주는 스팸 필터 학습 시스템이 있다고 하자. 이 경우 스팸 필터가 “시스템”이 되며 사용자는 “환경”이고 “데이터”는 메시지들과 이에 대한 사용자 행동의 관측값들로 구성된다. 여기서 “성능”은 제시해 준 메시지 개수에 대한 사용자가 읽은 메시지의 개수 즉 얼마나 효과적으로 메일을 여과해 주는지로 측정된다.

이 글은 기계학습 기술을 개괄적으로 살펴보고 앞으로의 연구 방향에 대해서 논의하는 것을 목표로 한다. 이를 위해서 지금까지 제시된 기계학습 모델과 알고리즘을 다양한 각도에서 구분하고 그 특성을 분석한다. 마지막으로 U-환경, 모바일 웹, 디지털 컨버전스, 나노기술, 생명과학 연구 환경에서의 인공지능을 위한 차세대 기계학습 기술의 연구 방향을 제안하고 토론한다.

2. 역사 및 응용 분야

기계학습이라는 용어가 처음 문헌에 등장한 것은

1959년 Samuel의 논문 “Some Studies in Machine Learning Using the Game of Checkers”에서이다[1]. 그는 게임보드의 패턴으로 정의된 특징과 가중치의 곱의 합으로 평가함수를 정의하고 가중치를 변경함으로써 게임을 학습하는 방법을 제안하였다. 또한 비슷한 시기에 Rosenblatt은 신경망 모델의 일종인 퍼셉트론과 그 학습 알고리즘을 제시하였다. 1975년에 Winston은 건축물의 아치모양을 예로부터 학습하는 기호적인 개념 학습 프로그램을 개발하였다[2].

이러한 태동기의 아이디어에 기반하여 기계학습이 하나의 새로운 연구 분야로 자리잡기 시작한 것은 1980년대 중반에 이르러서이다. 1983년과 1986년에 Machine Learning: An Artificial Intelligence Approach의 Volume I과 II가 발간되어 기호적 기계학습 연구의 기반이 마련되었다[3,4]. 1986년에는 Rumelhart & McClelland의 Parallel Distributed Processing 모델에 관한 연구 결과가 두 권의 책으로 정리되어 발표되면서[5] 연결론적 기계학습 연구가 시작되었다. 여기에 Valiant가 같은 해인 1986년에 Communications of the ACM에 “A Theory of the Learnable”이란 제목의 계산학습이론(Computational Learning Theory) 논문을 발표하면서 기계학습이 계산이론과 접목되면서 이론적인 틀을 갖추기 시작하였다.

다른 한편, 1980년대 중반부터 Uncertainty in Artificial Intelligence(UAI)나 Artificial Intelligence and Statistics(AI & Stats) 등의 학술대회를 통해서 통계학과 인공지능이 결합되는 시도가 일어나고 이들이 마침내 Pearl의 Probabilistic Network 연구, Lauritzen과 Jensen 등의 Graphical Model 연구, Neal의 Belief Network 연구, Hinton의 Helmholtz Machine 연구, Vapnik의 Statistical Learning Theory, Schoelkopf의 Kernel Machine 연구 등을 통해서 기계학습에 대한 수학적, 확률통계학적인 기반이 마련되면서 기계학습이 엄밀한 학문 및 기술 분야로 정립되기 시작했다. 1990년대 중반 이후에는 인터넷과 웹이 활성화되고 데이터마이

* 중신회원

표 1 기계학습의 응용 분야

응용 분야	적용 사례
인터넷 정보검색	텍스트 마이닝, 웹로그 분석, 스팸 필터, 문서 분류, 여과, 추출, 요약, 추천
컴퓨터 시각	문자 인식, 패턴 인식, 물체 인식, 얼굴 인식, 장면전환 검출, 화상 복구
음성인식/언어처리	음성 인식, 단어 모호성 제거, 번역 단어 선택, 문법 학습, 대화 패턴 분석
모바일 HCI	동작 인식, 제스처 인식, 휴대기기의 각종 센서 정보 인식, 떨림 방지
생물정보학	유전자 인식, 단백질 분류, 유전자 조절망 분석, DNA 칩 분석, 질병 진단
바이오메트릭스	홍채 인식, 심장 박동수 측정, 혈압 측정, 당뇨치 측정, 지문 인식
컴퓨터 그래픽	데이터기반 애니메이션, 캐릭터 동작 제어, 역운동학, 행동 진화, 가상현실
로보틱스	장애물 인식, 물체 분류, 지도 작성, 무인자동차 운전, 경로 계획, 모터 제어
서비스업	고객 분석, 시장 클러스터 분석, 고객 관리(CRM), 마케팅, 상품 추천
제조업	이상 탐지, 에너지 소모 예측, 공정 분석 계획, 오류 예측 및 분류

닝이 새로운 산업으로 등장하면서 기계학습은 그 핵심 기술로 자리매김하게 되었다.

현재 기계학습은 인터넷 정보검색, 텍스트 마이닝, 생물정보학, 바이오메트릭스, 자연언어처리, 음성인식, 컴퓨터비전, 컴퓨터그래픽, 로보틱스, HCI, 통신사업, 서비스업, 제조업 등 거의 모든 분야에서 활용되는 핵심 기반 기술이다(표 1).

예를 들어, 인터넷 쇼핑몰 운영자는 고객에게 개인화된 양질의 서비스를 제공하고 보다 직접적인 마케팅 전략을 세우기 위해서 웹로그 파일을 데이터마이닝하기 위해 기계학습 기술을 이용한다. 컴퓨터그래픽 연구자는 모션 캡처 데이터를 기계학습하여 사람처럼 자연스러운 동작을 재현하는 애니메이션 모델을 자동으로 생성한다. 생명과학 연구자는 DNA 칩을 이용한 유전자발현 데이터로부터 암에 관련되는 질병에 직접적인 영향을 주는 유전자를 찾아내기 위해서 기계학습 기반의 지식 발굴 기술을 사용한다. 모바일 환경에서 휴대기기를 편리하게 조작하기 위해서 다양한 센서 정보에 기반하여 기기의 움직임을 인식하는데 기계학습 알고리즘이 적용되고 있다.

3. 기계학습의 분류

기계학습 시스템은 학습 데이터를 획득하는 방법, 모델의 표현 구조, 데이터로부터 모델을 생성하는 학

습 알고리즘에 의해 구별된다. 즉 “기계학습 모델 = 데이터획득 방식 + 모델 구조 + 학습 알고리즘”로 나타낼 수 있다. 여기서는 각각의 요소에 대해서 알아본다.

3.1 학습 시스템의 분류

환경으로부터 받는 학습에 필요한 정보 또는 데이터가 어떤 형태인지에 따라서 기계학습은 감독 학습, 무감독 학습, 강화 학습의 세 가지로 구분된다(표 2). 감독 학습(supervised learning)은 입출력의 쌍으로 구성된 학습 예제들로부터 입력을 출력으로 사상하는 함수를 학습하는 과정으로 볼 수 있다. 무감독 학습(unsupervised learning)의 경우는 학습으로 입력은 주어지나 대응되는 출력이 없으며 이 경우 입력 패턴들에 공통적인 특성을 파악하는 것이 학습의 목적이다. 강화 학습(reinforcement learning)은 감독학습과 무감독 학습의 중간형태로서 입력에 대해 학습자가 행동을 선택하고 그 행동에 대해서 교사가 보상치를 제공하면 이에 따라서 학습한다. 보상치는 감독학습에서 주어지는 입력에 대한 올바른 출력값이 아니라 학습자 자신의 출력에 대한 평가치이다. 감독학습과 무감독 학습에서는 학습 시점에서 모든 데이터가 주어지는데 반해서 강화학습에서는 학습 신호가 시간적인 지연을 가지고 순차적으로 일어난다.

수학적으로, 학습 시스템은 함수 또는 사상 $f(x; M)$ 을 관측 데이터로부터 구성하는 것이다. 여기서 학습 모델 M 은 구조 S 와 파라미터벡터 W 로 구성된다. 감독 학습은 입력벡터 x 와 이에 대한 올바른 응답 d (desired output)를 학습 데이터로 제공 받는 경우로서 즉 학습 데이터 $D=\{(x, d)\}$ 에 기반하여 학습자는 관측하지 않은 새로운 문제 x' 가 들어왔을 때 이로부터 올바른 해답 d' 을 추론하는 방법을 배우게 된다. 감독 학습은 주로 패턴 인식, 질병 진단, 문서 여과, 주가 예측 등의 분류(classification)와 회귀 분석(regression) 문제 해결에 적합하다.

무감독 학습의 경우에는 문제 x 들의 집합만이 주어지고 대응하는 답들은 존재하지 않는 경우로서 학습 데이터는 $D=\{x\}$ 이다. 이 경우에 학습자는 x 들간에 존재하는 유사성에 근거하여 x 의 집합을 군집화(clustering)하거나 x 의 밀도함수(density function)를 추정하는 일을 한다. 앞에서 언급한 전자메일 스팸 필터의 경

표 2 문제(학습 데이터)의 유형에 따른 기계학습의 분류

학습 방법	학습 문제의 예
감독 학습	인식, 분류, 진단, 예측, 회귀분석
무감독 학습	군집화, 밀도추정, 차원 축소, 특징추출
강화 학습	시행착오, 보상 함수, 동적 프로그래밍

우 메일문서들을 군집화함으로써 문서들의 무감독학습을 통해서 문서들의 특성을 파악할 수 있고 이를 기반으로 나중에 어떤 군집의 문서에 대해서 스팸으로 규정할 수 있는지를 파악할 수 있다. 무감독 학습은 차원 축소, 특징 추출에도 사용하며 가시화를 통해서 데이터마이닝과 지식 발굴의 도구로서 유용하다.

강화 학습의 경우에는 입력벡터 x 에 대해서 출력이 주어지기는 하나 이것이 원하는 목표 출력 d 가 아니고 학습자가 출력한 예측치 y 에 대한 평가치 c (critique)가 주어진다. 즉 학습 데이터가 $D=\{(x,c)\}$ 로 주어지며 일반적으로 c 는 x 에 대한 올바른 목표 출력치 d 가 아니라 이에 대한 평가치만을 제공한다. 강화학습은 자율 이동 로봇, 온라인 게임, 주식 투자 등의 상황과 같이 순차적인 의사 결정 과정에 관여한다. 예를 들면, 장기를 두는 프로그램을 학습 시킬 때 학습자가 수(move)를 결정했을 때 그 수가 얼마나 좋은지를 $c \in [0, 1]$ 의 상수값으로 평가해서 학습자에게 정보를 전달하는 경우이다. 이러한 간접적인 학습 정보 c 는, 학습자가 둔 수 y 에 대해서 이것이 아닌 다른 수 d 를 두었어야 한다고 가르쳐 주는 감독학습의 경우와는 대조적이다.

스팸필터의 경우에는 학습시스템이 스팸메일 x 에 대해서 이것이 스팸인지 아닌지의 두 가지만을 구별하면 되므로 즉 $d=1$ or $d=0$ 또는 $c=1$ or $c=0$ 이 경우 감독학습과 강화학습이 상당히 유사하다. 그러나 감독 학습의 경우에는 모든 학습 데이터 집합 D 가 학습을 시작할 때 이미 주어져 있는 것을 가정하는데 반해서 강화학습은 보통 학습 집합 D 가 학습 시스템 수행이 이루어지는 사이에 순차적으로 결정되는 것이 일반적이다. 또한 보상치가 시간적인 지연을 가지고 제공되는 것이 보통이기 때문에(게임의 경우 승부가 결정된 후에야 중간과정에 대한 올바른 보상치를 제공 가능) 동적 프로그래밍을 이용해 재귀적 학습이 필요하다. 강화학습에서는 이러한 온라인 특성은 목표 함수가 시간에 따라 변할 수도 있는 것을 의미하며 따라서 수렴이 보장되지 않을 수도 있다.

3.2 학습 모델 구조의 분류

학습 시스템이 일을 수행하기 위한 함수 $f(x;M)$ 를 어떻게 표현하는지에 따라서 모델 $M=(S, W)$ 의 구조 S 는 논리식, 규칙, 함수, 트리, 그래프 등 다양하다. 표 3에는 이들 표현 구조와 그 사례들을 기술하고 있다. 기호적 인공지능 패러다임하에서는 명제 논리 등에 기반한 논리식이나 If-Then 규칙에 기반한 표상을 사용한 기계학습 방식이 많이 연구되었다.

표 3 학습 모델 표현 구조의 종류

모델 구조	표현	기계학습 모델 예
논리식	명제 논리, 술어논리, Prolog 프로그램	Version Space, 귀납적 논리 프로그래밍(ILP)
규칙	If-Then 규칙, 결정규칙	AQ
함수	Sigmoid, 다항식, 커널	신경망, RBF 망, SVM, 커널 머신
트리	유전자 프로그램, Lisp 프로그램	결정 트리, 유전자 프로그래밍, 뉴럴트리
그래프	방향성/무방향성 그래프, 네트워크	확률그래프 모델, 베이지안망, HMM

신경망이 등장한 1980년대 중반 이후로는 다양한 종류의 수치적인 기저 함수(basis function)들의 결합으로 구성된 모델 구조들이 연구되었다. 예를 들어, 뉴런의 활성화 함수를 모사한 시그모이드 함수나

$$f(x_1, \dots, x_n) = \left(1 + \exp\left(-\sum_{i=0}^n w_i x_i\right)\right)^{-1}$$

단순한 선형적 가중치 결합 함수

$$f(x_1, \dots, x_n) = \sum_{i=0}^n w_i x_i$$

또는 이를 일반화한

$$f(x_1, \dots, x_n) = \sum_{i=0}^n w_i \phi(x_i)$$

와 같은 구조가 대표적인 예이다. 최근에 많이 연구되고 있는 지지벡터머신(SVM)을 포함한 커널 머신 계열의 학습 모형은 이러한 모델의 연장선상에 존재한다.

한 편 트리를 기본 표현 구조를 사용하는 학습 방식으로 결정트리나 유전자 프로그래밍이 있다. 보다 일반적인 그래프나 네트워크 구조를 사용하여 결합확률분포나 지식 노드 x_i 와 부모 노드 $pa(x_i)$ 간의 조건 확률분포

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | pa(x_i))$$

를 표현함으로써 데이터의 구조를 학습하는 확률그래프 모델 등이 사용되고 있다.

3.3 학습 알고리즘의 분류

알고리즘 관점에서는 크게 미분과 같은 연속적인 수치 계산을 통해서 오차를 수정하는 수치해석적인 기계학습 알고리즘과 연속이 아닌 구조나 파라미터를 변경하는 이산적인 학습 알고리즘으로 구별할 수 있다.

표 4 학습을 위한 목표 함수의 종류

학습 알고리즘	설명	예
오류 최소화	오류 절대값, 분류 오류률	퍼셉트론, 다층 신경망, 커널 머신
최대 가능성도	학습데이터 생성확률 최대화	통계적 학습 모델, 기대치 최대화(EM)
최대사후확률	최대 가능성도에 사전 확률 모델 고려	베이저안망, 확률 그래프 모델(PGM)
베이저안학습	가능한 모델들의 전체 분포를 추정	MCMC 기반 학습 모델
정보이론적 학습	엔트로피, 정보이득, 상대 엔트로피	볼츠만 머신, 결정트리

학습 모델이 이산적인 구조와 연속적인 파라미터값으로 구성되었을 경우 이 둘을 모두 학습할 수도 있고 경우에 따라서는 이산적인 모델 구조는 고정된 상태에서 수치적인 파라미터만을 주로 학습하는 모델들도 존재한다. 그러나 최종 학습 성능은 구조와 파라미터 모두에 의존한다.

표 4는 현존 학습 알고리즘에서 많이 사용되는 학습 목표 함수를 요약 정리한 것이다. 대부분의 학습 알고리즘들이 학습 데이터 집합 D 에 대한 오류치 또는 오분류율을

$$E_D(M) = \frac{1}{N} \sum_{n=1}^N (d_n - f(x_n; M))^2$$

최소화하는 것을 목표로 한다. 여기서 $f(x_n; M)$ 은 입력 x_n 에 대한 학습 모델 M 의 실제 출력(예측치)을 의미한다. 이 값은 원하는 출력 d_n 와 비교되어 그 차를 줄이는 방향으로 모델 M 의 구조 S 나 파라미터 W 가 수정되어 학습이 이루어진다.

확률 모델의 경우에는 주어진 데이터의 관측할 확률을 최대화하는

$$\operatorname{argmax}_M \{P(D|M)\}$$

최대가능도(ML) 추정법이나, 여기에 모델들의 사전 확률을 추가로 고려하여 학습하는

$$\operatorname{argmax}_M \{P(D|M)P(M)\}$$

최대 사후 확률(MAP) 추정법을 사용한다. 가장 일반적인 모델은 베이저안 추론 규칙을 직접 사용하는 것이다.

$$P(M|D) = \frac{P(D|M)P(M)}{P(D)}$$

이것은 사전확률 $P(M)$ 과 가능성도 $P(D|M)$ 를 결합하여 사후확률분포 $P(M|D)$ 를 추정하고 이 분포를 이용하여 모델을 구성하는 학습 방법이다. 이 방법은 이상적

이기는 하나 모든 가능한 모델의 전체 공간을 탐색해야 하기 때문에 정확한 계산이 실제적으로는 불가능하다. 그러나 최근에 컴퓨팅 파워의 증가로 Markov Chain Monte Carlo(MCMC) 등의 확률적 샘플링 방법을 사용하여 근사적으로 베이저안 추론을 하는 연구가 활발히 이루어지고 있다.

정보 이론에 기반한 목표 함수들도 기계학습에 많이 활용된다. 예로서 결정트리 학습에서는 변수 x_i 가 학습데이터 D 의 엔트로피 $H(D)$ 를 줄이는데 기여하는 정도 즉 정보 획득(information gain)을 정의하고

$$\operatorname{Gain}(D, x_i) = H(D) - \sum_{v \in \text{values}(x_i)} \frac{|D_v|}{|D|} H(D_v)$$

이를 최대화하는 변수들을 우선적으로 선택하여 모델을 구성한다.

다른 예로서, 무감독 학습 방법으로 정보량이 많은 특징을 추출하기 위해서 상호정보(mutual information)가 종종 사용된다.

$$MI(X; Y) = \sum_{x,y} P(x,y) \ln \frac{P(x,y)}{P(x)P(y)}$$

이 측도는 두 개의 변수간의 상호 의존성이 강한 정도를 측정한다. 즉 두 변수가 서로 독립이라면 결합 확률값과 각각의 확률값의 곱이 같게 되어, 즉 $F(x,y) = F(x)F(y)$, 상호정보량은 0이 되고 그렇지 않은 경우 양의 값을 갖는다.

정보 이론에 기반한 학습 목표 함수로 가장 일반적인 형태는 KL-Divergence로도 알려진 상대엔트로피이다.

$$D_{KL}(P||Q) = \sum_x P(x) \ln \frac{P(x)}{Q(x)}$$

이것은 두 개의 확률 분포 P 와 Q 가 있을 때 Q 에 대한 P 의 상대적인 엔트로피(비대칭)값을 나타낸다. 이를 추정하기 위한 학습 알고리즘으로 MCMC 계열의 확률적 샘플링 방법을 주로 사용한다.

4. 기계학습 현재 기술 수준

이 절에서는 현재 실제 문제 해결에 많이 활용되고 있는 기계학습 모델의 최신 연구 동향을 알아본다. 이를 통해서 현재 기술 수준을 파악하고 새로운 문제 해결에 가장 적합한 기계학습 모델을 선택하는 기준을 마련할 수 있을 것이다.

4.1 학습 모델의 종류 및 특징

현재 가장 많이 사용되는 기계학습 모델은 주로 군

집화를 위한 무감독 학습 알고리즘과 패턴 분류를 위한 감독학습 모델들이다. 무감독학습 알고리즘의 대표적인 예로는 K-Means, 계층적 군집화, 자기조직지도(SOM) 등이 있다. 감독학습의 대표적인 예로는 다층신경망(퍼셉트론), 지지벡터머신(SVM), 커널 머신, 결정트리, 나이브베이스, K-최근점 분류기(KNN), 베이지안 망, 은닉마코프모델(HMM), 잠재변수모델 등의 확률그래프 모델이 있다. 감독학습과 무감독 학습은 실제 산업적으로 많이 활용되고 있다. 반면에 강화 학습은 많은 이론적인 발전을 이룩했음에도 불구하고 문제 자체의 어려움으로 인해 학습 에이전트와 로봇틱스 분야에서 일부 활용되고 있다. 강화 학습은 기본적으로 시행착오에 기반해 있기 때문에 수렴하는 성능을 얻기까지 많은 학습 시간을 필요로 한다.

각 기계학습 모델들에 대한 특징을 간략히 요약하여 기술하면 다음과 같다.

- * K-평균벡터(K-Means): 예제의 평균벡터 저장, EM 방식 학습, 잡음에 견고함.
- * 계층적 군집화(HC): 전체 데이터를 계층 구조로 분할, 다차원 데이터의 시각화에 유용.
- * 자기조직지도(SOM): 층구조 신경망, 출력층이 격자 구조, 경쟁 학습, 데이터 가시화에 유용.
- * 다층퍼셉트론(MLP): 층구조, 시그모이드 뉴런, 에러 수정, 잡음에 견고, 이산치/연속치 입출력 사상.
- * 방사형기저함수망(RBF): 층구조, 가우스함수 뉴런, 선형모델, 빠른 학습.
- * 지지벡터머신(SVM): 마진 최대화, 정규화, 예측 성능 우수, 이진 분류, 빠른 학습.
- * 커널 머신(KM): 커널 트릭, 차원 확장, 고차원 공간에서 선형 분리, 이진 분류, 커널 정의 필요.
- * 결정트리(DT): 트리 구조, 데이터 공간의 순차적 분할, 엔트로피기반 정보획득, 규칙으로 변환 가능.
- * 유전자 프로그래밍(GP): 프로그램 트리, 진화에 의한 학습, 변이와 선택, 개체군 기반 병렬 탐색.
- * 귀납적 논리프로그래밍(ILP): 술어논리 프로그램 학습, 사람 이해 용이.
- * K-최근점(KNN): 학습에 저장, 암기식 학습, 제일 가까운 K개의 최근점의 투표, 모든 학습에 저장 필요.
- * 사례기반학습(CBR): KNN과 유사, 기호적인 표현 구조, 프로토타입기반 학습 방식과 유사.
- * 베이지안망(BN): 방향성 그래프(DAG) 구조, 확률적 모델, 변수간 의존 관계 분석.
- * 나이브베이스(NB): 분류 모델, 변수들간 독립 가정, 베이지안망의 특수한 경우.

- * 은닉마코프모델(HMM): 방향성 그래프, 순차적 데이터 모델링, 확률적 모델, 생성 모델.
- * 마코프 랜덤필드(MRF): 무방향 그래프, 결합분포 추정, 클릭에 전위 함수 정의.
- * 조건부 랜덤필드(CRF): 무방향 그래프, 조건부 확률분포 추정, 마코프 가정(인접 노드에만 의존).
- * 잠재변수모델(LVM): 혼합(mixture) 모델, 잠재 변수 가정, 차원 축소, 요인 분석.
- * 가우시안혼합모델(GM): 가우시안 함수의 혼합 모델, 잠재변수 모델, EM 학습.
- * 주성분 분석(PCA): 분산이 큰 차원, 특징 추출, 차원 축소.
- * 독립성분 분석(ICA): 독립적인 성분으로 분리, Blind Source Separation, 요인 분석.
- * 가우시안 프로세스(GP): 회귀분석 모델, 커널 머신, RBF와 유사.
- * 지역가중치회귀분석(LWR): 회귀분석 모델, KNN 및 RBF와 유사.
- * 홉필드망(HN): 완전 그래프, 동적 활성화, 제약 조건 만족, 학습 없음, 기억 회상, 최적화 문제 해결.
- * 볼츠만 머신(BM), 헬름홀츠 머신(HM): 은닉 변수를 가진 층형 망구조 모델, 확률적 생성 모델.
- * 에이다부스트(AdaBoost): 기본학습기의 가중치 앙상블 머신, 메타학습, 분산의 감소 효과.

이들 모델의 구조와 학습에 대한 보다 상세한 정보는 참고문헌에 나온 교과서를 참고하기 바란다. 그 중에서 [6], [7], [8], [9]는 기계학습의 전반적인 내용을 포괄적으로 다루고 있다. 확률 그래프 모델에 보다 전문적인 소개서로서 [10]과 [11]이 있으며 [12]와 [13]은 커널 머신에 대해 잘 다루고 있다.

표 5에는 기계학습 분야의 주요 저널과 전문 학술대회를 열거하고 있다. 보다 최신의 연구 및 기술 동향 파악을 위해서는 관련된 웹사이트를 방문할 수 있다.

표 5 기계학습 분야 주요 저널 및 전문학술대회

구분	예
저널	- Machine Learning(MLJ) - Journal of Machine Learning Research(JMLR) - Neural Computation(NCJ) - Evolutionary Computation(ECJ)
학술대회	- Int. Conf. on Machine Learning(ICML) - European Conf. on Machine Learning(ECML) - Int. Conf. on Comp. Learning Theory(COLT) - Neural Information Processing Systems(NIPS)

표 6 최신 기계학습 모델의 세계적 선두 연구 그룹

학습 모델	연구 그룹의 예
커널 머신 연구 그룹	- MIT의 Poggio 그룹 - Max-Planck 연구소의 Schoelkopf 그룹 - Bell Labs의 Burge 그룹 - Southampton 대학의 Shawe-Taylor 그룹 - UC Davis의 Cristianini 그룹 - TU Berlin의 Obermayer 그룹
확률 그래프 모델 연구 그룹	- Toronto 대학의 Hinton, Neal, Frei 그룹 - Stanford 대학의 Koller 그룹 및 Thrun 그룹 - MIT의 Tenenbaum 그룹 - Microsoft 연구소의 Bishop 그룹 및 Heckerman 그룹 - Cambridge 대학의 MacKay 그룹 및 Ghahramani 그룹 - UC Berkeley의 Jordan 그룹, Russel 그룹, Griffith 그룹
기호적 학습 연구 그룹	- CMU의 Mitchell 그룹 - King's College의 Muggleton 그룹 - Bonn대학/Fraunhofer 연구소의 Wrobel 그룹 - Georgia Tech의 Kolodner 그룹

4.2 최근 연구 동향

최근 기계학습 연구는 커널 머신과 확률 그래프 모델에 상당히 집중되어 있다. 그 외에 웹 정보 검색이나 바이오 데이터 분석 등에서 해석의 필요성에 따라 기호를 사용한 명시적인 학습에 대한 중요성이 다시 부각되고 있다. 이 분야의 선두적인 연구 그룹을 표 6에 예시하였다.

이 세 가지 모델계열은 그 장단점이 많이 다르다. 커널 머신은 선형대수에 이론적 기반을 두고 있으며 학습 속도가 빠르고 예측 성능이 좋은 장점이 있다. 입력변수는 이산치 또는 연속치를 모두 취할 수 있으나 출력은 이진값만 가능하다. 따라서 이진 분류 문제에 주로 적합하며 결과를 설명하는 모델로서는 적합하지 않은 단점이 있다. 또한 학습 속도가 데이터의 입력 차원수에 대해서는 무관하기 때문에 아주 큰 차원의 데이터를 분류하는 데 적합한데 반해서 학습 데이터의 개수에 비례하여 학습 속도와 메모리 용량이 증가하기 때문에 많은 수의 데이터를 학습하는데에 기술적인 어려움이 있다.

확률 그래프 모델은 커널 머신과 다른 장단점을 가진다. 즉 학습이 느리고 예측 성능이 별로 좋지 않지만 반면 확률적인 상관관계를 분석하고 가시화할 수 있어 데이터를 묘사/설명하는 모델로 적합하다. 최근 데이터마이닝과 지식발견 관점에서 많이 사용되고 있다. 분류 문제 해결을 위해서는 나이브베이스와 같은 성능이 안정된 간소화된 확률 그래프 모델도 유용하다. 반면 확률 그래프 모델은 확률 변수를 입출력 변

수로 다루기 때문에 수치 데이터를 처리하기 위해서는 이산화 과정을 거쳐야 한다. 모델 구조 즉 그래프의 구조 학습을 위해서는 시간이 많이 걸리며 대규모 확률 그래프 망을 구성하는 효율적인 알고리즘이 연구되어야 한다.

기호적 학습 모델은 주로 논리식이나 If-Then 규칙과 같은 기호적인 표현 구조를 사용하며 귀납적 논리 프로그래밍, 사례 기반 학습, 유전자 프로그래밍 등이 그 대표적인 예이며 이산적 변수를 갖는 결정 트리도 여기에 속한다. 논리식에 기반한 기호적 표현은 보통 규칙 형태로 기술이 자연스럽기 때문에 그 결과를 사람이 이해하거나 이로부터 규칙을 추출하는데 아주 유용하다. 반면, 기호적인 이산 구조만을 다루기 때문에 수치 데이터 처리가 어렵다. 기호적 학습 기법은 신경망 기법이 등장한 후 한 때 연구가 소홀하였으나 최근에 웹이나 인터넷의 정보 등 비정형화된(벡터형이 아닌) 기호적 데이터로부터 데이터마이닝과 지식추출이 새로운 이슈로 등장함에 따라 다시 그 중요성이 부각되고 있다.

5. 차세대 기계학습 기술 연구 방향

5.1 기계학습 연구 접근 방법

기계학습은 컴퓨터과학자(특히 인공지능연구자)와 수리과학자(특히 확률통계학자)들이 학제적인 연구를 통해서 발전되었다. 최근에는 인지과학자(특히 심리학자와 언어학자)와 신경과학자(생물학자)도 기계학습 연구에 참여하고 있다. 표 7은 기계학습 연구를 위한 다양한 접근 방법을 학문 분야별로 요약정리하고 있다.

표 7 기계학습 연구의 접근 방법

접근 방법	구체적 사례	주요 관심사
컴퓨터 과학적	일반화와 특수화 연산자, 오류 수정 알고리즘, 과다 학습, 모델 선정, 지식 표현, 목표 함수, 능동 학습	인공적인 시스템 구현을 통한 효율적 문제 해결 및 이의 과학기술적 응용
수학적	선형 대수, 확률론, 통계학, 정보이론, 그래프 이론, 미적분, 동력학, 함수론, 최적화	형식적인 문제 정의, 특성 분석, 계산학적 해결 가능성 규명
인지 과학적	인간의 기억과 학습, 장기 기억, 단기 기억, 언어 능력, 지각 능력, 의사 결정, 행동 학습	인간의 학습 능력 이해 및 이의 질병 치료 및 교육 등에의 활용
생물학적	생리학적, 분자생물학적, 생화학적, 유전학적, 세포생물학적, 시스템신경과학적	학습과 기억 능력의 생물학적 기반 규명 및 이상 현상 연구

지금까지의 기계학습 연구는 주로 컴퓨터과학자나 수학자의 계산과학적인 관점에서 발전하였다. 그러나 앞으로 인지과학적 생물학적 관점에서의 연구가 활발히 이루어질 것으로 기대된다. 최근 들어 인지과학이나 신경과학 분야에서 사람의 학습과 기억에 관해 새로운 실험 결과들이 데이터베이스화되어 축적되고 있다. 뇌 활동의 사진을 찍은 fMRI 이미지 데이터베이스가 그 대표적인 예이다. 이러한 데이터를 현재의 기계학습 기술을 이용하여 모델링함으로써 새로운 인지신경과학적인 발견을 이룰 수 있다. 이는 마치 유전체 데이터를 기계학습으로 분석하여 유전학에서 새로운 발견을 하는 것과 같다. 이러한 모델링 연구는 반대로 컴퓨터과학자로 하여금 인간의 학습 패턴을 닮은 기계학습 모델을 개발할 수 있게 하는 통찰력을 제시해 줄 것이다.

5.2 기계학습의 근본 원리

현재의 기계학습 기술은 알고리즘 수준에서 많은 발전을 이룩하였다. 그러나 보다 더 근본적인 이론적 질문에 대해서는 아직 많은 연구가 필요하다. 예를 들어서, 학습시 모델의 최적 구조를 결정하는 것은 쉬운일이 아니다. 이것은 가용한 학습 데이터의 크기와 품질 등과 관련되며 이에 대한 일반적인 가이드라인을 제시하는 것은 기계학습에서 아주 근본적이고 중요한 연구이다. 표 8에는 이러한 학습 이론적인 고찰의 예로서 세 가지의 학습 원리를 요약하였다.

첫 번째의 균등의 원리(The Principle of Indifference)는 데이터를 관측하기 전에는 불필요한 가정을 최소화하라는 원리이다. 즉 특별히 차이가 나는 것으로 알려진 것이 아니라면 모든 가능한 모델들에 대해서 동등한 확률 즉 $P(x) = 1/n$ 을 부여하라는 원리이다. 이 원리는 시스템 전체의 엔트로피 $H(X) = -\sum_x P(x) \log P(x)$ 를 최대화하는 즉 최대 엔트로피 원리의 특별한 경우로 볼 수 있다.

표 8 기계 학습의 근본 원리

원리	설명/해석
균등의 원리(Principle of Indifference)	차이를 증명할 만한 데이터를 관측하기 전에는 구별하지 않는다.
오캄의 원리(Principle of Occam's Razor)	주어진 데이터를 설명하는 범위 내에서는 단순한 모델을 선호한다.
양보의 원리(Principle of No Free Lunch)	학습 알고리즘의 효율과 성능은 서로 양보해야 하는 관계이다.

두 번째의 오캄의 원리(The Principle of Occam's Razor)는 주어진 데이터를 설명하는 모델이 여러 개 있다면 그 중에서 단순한 모델을 복잡한 모델 보다 우선해서 선택하라는 원리이다. 이는 단순한 모델들이 가정이 적기 때문에 관측하지 못한 새로운 데이터를 설명할 때 통계학적으로 분산이 적은 답을 제시할 가능성이 높다는 사실에 근거해 있다.

세 번째의 양보의 원리(The Principle of No Free Lunch)는 학습 성능 향상에 관계하는 원리로서 이익을 보는 것이 있으면 손해를 보는 것도 있을 수밖에 없다는 즉 공짜로 얻는 성능향상은 없다는 것이다. 즉 학습 모델 또는 알고리즘 A1이 A2보다 문제 s1을 해결하는데 더 우수하다면 문제 s2를 해결하는데는 A1이 A2보다 못할 수도 있다는 것이다. 그 이유는 A1이 문제 s1을 잘 해결하기 위해 최적화하는 과정에서 여러 가지 가정(bias)이 들어가고 이는 s2를 해결하는데는 적합하지 않기 때문에 성능이 오히려 저하될 수 있기 때문이다.

학습 원리는 새로운 학습 모델이나 알고리즘 설계시 방향을 제시해 준다. 예를 들어, 모델의 구조를 고정시켜 놓고 파라미터만 학습함으로써 최대 일반화 성능에는 제한이 있지만 학습 속도가 아주 빠른 알고리즘 A1이 있을 수 있고, 이에 반해서 학습 시간은 많이 걸리지만 파라미터 뿐만 아니라 모델의 구조까지도 학습함으로써 일반화 성능이 더 좋을 가능성을 열어 둔 알고리즘 A2가 있을 때, A1과 A2가 모두 나름대로의 의미가 있을 수 있음을 암시한다. 어느 알고리즘이 더 적합한지는 응용 문제의 특성 및 요구 조건에 따라서 선택할 사항이다.

5.3 학습 모델의 종류

변별적/생성적 모델. 모델이 학습되는 방식에 따라서 기계학습은 변별 모델(discriminative model)과 생성 모델(generative model)로 나눌 수 있다. 전자는 차이점을 부각함으로써 데이터를 학습하는데 반해 후자는 학습 데이터들의 유사점을 파악하는 것에 역점을 둔다. 변별 모델들은 주로 분류(스팸메일 또는 정상메일)나 인식(스팸메일인지 여부 파악) 문제 해결에 이용되며 서로 다른 부류의 것들을 구별하는 것이 목적이기 때문에 각 클래스의 특성 자체 파악 보다는 서로 다른 클래스간의 구별되는 특징을 학습한다. 생성 모델들은 주로 데이터에 대한 확률 모델을 구성함으로써 만들어 지기 때문에 모델로부터 나중에 데이터를 재생성해 낼 수 있는 장점이 있다. 반면 모델에 대한 가정이 필요하거나 가정이 없는 경우 학습에 많은 데

이터와 학습 시간을 필요로 할 수 있다. 그러나 이러한 모델들은 주어진 데이터 집합을 잘 묘사하거나 설명하는데 유용하기 때문에 데이터마이닝 특히 과학적 데이터마이닝에 유용하다.

암묵적/명시적 모델. 인간의 학습은 의식하지 못하는 사이에 일어나는 암묵적 학습(implicit learning)과 의식적인 과정을 통해서 일어나는 명시적 학습(explicit learning)의 두 가지 측면을 모두 가지고 있다. 전자는 행동 학습과 같이 절차적인(procedural) 방법의 학습에 주로 이용되고 후자는 새로운 지식 습득과 같이 주로 선언적인(declarative) 표상을 학습할 때 사용된다. 현재 실용적으로 사용되는 대부분의 기계학습 방법들은 암묵적인 모델에 기반해 있다. 일부 기호적인 표현을 사용하는 학습 방식들이 명시적, 선언적인 학습을 하고 있다. 역사적으로 볼 때 1980년대까지는 기호적인 방법의 학습 연구가 많았으나 신경망 등장 이후에는 많은 연구가 암묵적인 학습에 초점이 맞추어졌다.

정적/동적 학습 시스템. 데이터의 획득 방식은 정적인 방법과 동적인 방법이 있다. 정적인 학습(static learning) 시스템은 학습이 시작될 때 이미 모든 학습 데이터가 주어져서 학습자는 수동적으로 이 고정된 데이터를 처리한다. 반면, 동적인 학습(dynamic learning) 시스템은 학습 데이터를 시행착오를 통해서 생성하거나 주어진 데이터에서 선별적으로 선택함으로써 점진적 능동적으로 학습한다. 고전적인 감독 및 무감독 학습은 주로 정적인 학습 방식으로 훈련되며 강화학습은 보통 동적인 학습 요소를 기본적인 특성으로 가지고 있다.

표 9 기계학습 모델의 분류 방식

분류 방식	모델	특성
모델 구축 방식	변별 모델	차이점 위주로 학습. 차별적, 분류적, 인식, 대부분의 감독학습이 이에 속함.
	생성 모델	유사점 위주로 학습. 묘사적, 설명적, 요인분석, 밀도 추정, 주로 무감독 학습이 이에 속함.
모델 표현 방식	암묵적 학습	무의식적, 절차적인 과정에 의해 기억됨. 주로 반복적인 훈련 과정을 거침. 수치적 표상. 모델 파라미터 습득
	명시적 학습	의식적, 선언적 표현으로 기억됨. 일회적 학습이 가능. 기호적 표상. 모델 구조 습득.
데이터 획득 방식	정적 학습	학습 데이터가 고정됨, 일시적 반복 학습, 수동적 학습, 고전적인 감독 학습과 무감독 학습.
	동적 학습	학습 데이터가 시간에 따라 변함, 강화 학습, 온라인 학습, 점진적 학습, 능동 학습.

지금까지의 기계학습 분류 방식 논의에 기반하여 차세대 기계학습 기술 연구는 크게 다음과 같이 세 가지 방향으로 나누어 생각할 수 있다.

- * 기존 모델의 개선
- * 통합 모델의 연구
- * 새로운 모델의 탐색

아래에서는 이들 각각에 대하여 구체적인 연구 주제를 기술하고 논의한다. 표 10은 이를 전체적으로 요약하여 정리한 것이다.

5.4 기존 모델의 개선

차세대 기계학습의 발전을 위해서 단기적으로는 기존 모델 내에서의 문제점을 개선하고 성능을 향상시키는 노력을 해야 할 것이다. 앞 절에서 살펴본 바와 같이 현재 가장 많이 활용되고 있는 기계학습 모델들도 아직 문제점들을 지니고 있다. 예를 들어서, 커널 머신의 경우 두 개 이상의 분류문제를 학습하는 다중 클래스 학습 알고리즘이 필요하며, 도메인에 따라서 적합한 커널을 자동으로 설계하는 방법에 관한 연구도 필요하다. 그리고 대규모의 학습 데이터 집합을 효율적으로 학습하기 위한 알고리즘도 연구되어야 한다.

확률 그래프 모델의 경우 대규모 그래프 구조 즉 변수의 수가 많은 문제를 효율적으로 학습하는 알고리즘이 존재하지 않는다. 대규모의 확률 그래프 모델을 학습하기 위한 고성능의 학습 알고리즘이 필요하다. 한편, 지금까지 제안된 확률 그래프 모델은 단순한 층구조나 제한된 DAG 구조에 기반하고 있다. 그러나 보다 일반적인 지식을 발굴하기 위해서는 그래프 구조의 표현력을 증가하여 고차의 상호작용을 나타내는 랜덤 그래프 구조 등을 연구할 필요가 있다. 이러한 연구는 특히 바이오네트워크 등에서 많은 분자들 간의 상호작용에 관여 하는 네트워크 모듈 등을 발굴하는데 유용할 것이다.

5.5 통합 모델 연구

앞에서 여러번 논의된 바와 같이 **현재 기계학습 연구에서의 큰 과제 중 하나는 생성 모델의 장점과 변별 모델의 장점을 결합한 새로운 통합된 학습 모델을 개발하는 것이다.** 생성 모델의 대표적인 예가 확률 그래프 모델이고 변별 모델의 대표적인 예가 커널 머신 계열이므로 이러한 연구는 커널 머신과 확률 그래프 모델의 장점을 모두 살리는 새로운 커널 기반 확률 그래프 모델과 같은 통합을 시도하는 것으로부터 출발할 수 있다.

표 10 차세대 기계학습 기술의 연구 방향

연구 방향	연구 내용의 예
기존 모델의 개선	<ul style="list-style-type: none"> - 대규모 확률그래프모델의 효율적 구조학습 알고리즘 - 고차의 상호작용을 학습하는 확률그래프 모델 - 대규모 학습 데이터에 대한 커널 머신 학습 알고리즘 - 다중클래스 분류 문제 해결을 위한 커널 기법
통합 모델 연구	<ul style="list-style-type: none"> - 커널 머신과 그래프 모델의 통합 학습 구조 연구 - 변별 모델과 생성모델의 장점을 살린 새로운 학습 모델 - 수치적 모델과 기호적 모델의 통합 표현 모델 연구 - 모델 파라미터와 모델 구조 학습의 균형적 통합 이론
새로운 학습 모델 탐색	<ul style="list-style-type: none"> - Life-Long Learning 상황에서 동작하는 학습 기술 연구 - 학습자가 스스로 학습 데이터를 획득하는 능동적 학습 - 효율적인 학습과 효과적인 학습을 위한 학습 능력과 표현력의 균형 - 동적 목표함수 환경에서 단기적 적응과 장기적 생존의 균형 유지 - 내재적 학습 능력을 보유한 새로운 정보 매체와 계산 모형 연구

또 다른 통합의 시도는 수치적 표상을 사용하는 암목적 모델과 기호적 표상을 사용하는 명시적 모델의 장점을 살리는 방법에 관한 연구이다. 커널 머신이나 확률 그래프 모델은 수치적인 학습에 상당히 의존하는 학습 모델들이다. 그러나 최근에 기계학습의 응용 범위가 넓어지면서 정형화된 벡터 형태의 데이터 외에도 다양한 종류의 비정형화된(semi-structured) 데이터가 등장하고 또한 그 해석의 중요성도 증가하고 있다. 이 경우 기호적인 데이터를 다루거나 아니면 학습 결과를 기호적인 표현으로 변환하여 제시할 수 있는 능력도 중요한 요건 중의 하나로 등장하였다. 특히 바이오 데이터와 같이 과학적인 데이터의 경우 과학자들이 결과를 이해하고 이를 검증하기 위한 실험을 수행하기를 원하기 때문에 모델의 설명력은 아주 중요한 이슈로 등장하였다. 이 관점에서 커널 머신보다는 확률 그래프 모델이 우수하다고 볼 수 있다. 그러나 확률 그래프 모델도 귀납적 논리 프로그래밍과 같은 기호적 표현에 비하면 표현 능력이 제한되어 있다. 따라서 확률 그래프 모델에 기호적 표현의 표현 능력을 부여하는 연구는 앞으로 기계학습에 있어서 아주 중요한 주제가 될 것이다.

모델의 복잡도는 학습의 일반화 능력에 많은 영향을 준다. 학습 모델은 모델 구조와 파라미터로 구성

되어 있으므로 일반화 능력의 향상을 위해서는 학습 알고리즘이 두 가지의 요인의 균형을 필요로 한다. 기호적 표상이나 그래프 모델의 경우는 구조 학습이 특히 중요하다. 반면 신경망이나 커널 머신 계열의 모델들은 구조보다는 파라미터 학습에 치중하는 경향이 강하다. 그 중간에 있는 방식들이 결정 트리와 같은 모델들이다. 앞의 학습 원리에서 살펴본 바와 같이 구조 학습을 통해서 시간은 더 걸리지만 좋은 결과를 얻을 수 있는 방법과 파라미터만의 조정을 통해서 적당한 결과를 빨리 획득하는 방식간에 서로 득실이 있으며 이들은 서로 양보해야 하는 관계에 있다.

5.6 새로운 모델의 탐색

차세대 기계학습 연구의 또 다른 방향은 모델이나 이론 또는 응용 관점에서 새로운 길을 모색하는 연구를 하는 것이다. 점차 현실적인 문제를 다루게 됨으로써 예전에 생각하지 못했던 기계학습 문제들이 대두되며 이의 해결을 위해서는 지금까지와는 전혀 다른 모델이나 이론이 필요하게 된다. 이러한 예 중의 하나는 부분감독 학습(semi-supervised learning)이다. 웹 정보검색 도메인에서는 일부 학습 데이터는 목표 표지 값을 가지고 있으나 대부분의 데이터는 표지가 되어 있지 않다. 이 경우 표지된 데이터를 이용하여 표지 없는 데이터를 학습에 활용하기 위한 방법이 중요하다.

Life-Long Learning. 아주 중요한 이슈 중의 하나는 평생학습(Life-Long Learning) 환경이다. 사람의 경우 학습은 일생동안 계속된다. 앞서서도 언급하였듯이 학습은 시간에 관한 함수이며 환경과의 상호작용에서 오랜 시간에 따른 변화에 적응해 나갈 수 있는 능력은 기계학습의 가장 중요한 요소이다. 많은 소프트웨어와 서비스가 개인화된 맞춤형으로 변화하고 있다. 이 경우 학습 시스템이 평생학습의 개념 즉 고정된 학습 데이터가 주어졌다고 가정하기 보다는 학습 데이터가 수행되는 동안 계속하여 발생하는 것을 가정하고 학습해야 할 것이다. 현재 플래쉬 메모리 기술 등 메모리 용량과 성능의 향상에 따라서 실제로 Microsoft에서는 SenseCam 카메라를 이용하여 일상생활 중의 모든 센서 데이터를 수집한 후 이들을 궁극적으로 모두 데이터베이스화하고 검색하려는 MyLifeBits 프로젝트가 진행 중이다[14]. 이러한 환경에서 문맥에 기반한 연상작용을 이용한 정보의 저장과 검색이 필요할 것이며 기계학습 기술은 여기에 아주 중요한 역할을 할 것이다.

Active Learning. 사람의 경우 주변에서 습득하는 모든 데이터를 그대로 받아들이지 않는다. 선택적 주의

집중(selective attention)에 의하여 필요한 데이터만을 능동적으로 선별하여 학습한다. 기계학습에 있어서도 데이터를 집진적으로 선택하며 능동적으로 학습하는 것이 주어진 학습 데이터를 모두 그대로 사용하는 것보다 효율적이라는 것이 보고된 바 있다[15]. 특히 평생학습 시스템과 같이 장기적인 온라인 스트림 데이터를 다루는 경우 능동적인 데이터 선별 능력은 중요하다. 산업적으로도 능동형 학습은 맞춤형 서비스 분야 등에서 아주 중요하다. 예를 들어서, 현재는 정해진 곳에 가서 데이터나 문헌을 검색해 와서 이를 학습 데이터로 해서 모델을 학습하고 예측하지만, 맞춤형 정보서비스가 보편화된 환경이 되는 차세대의 정보서비스 시스템에서는 사용자의 검색 패턴을 학습해서 자동으로 그리고 시스템이 능동적으로 필요한 데이터와 문헌을 검색해서 사용자에게 맞춤형으로 제공해 주고 그 결과에 대한 사용자의 반응을 감지해서 이를 다시 학습데이터로 사용하여 다음번에 정보를 제공할 때 참고하게 될 것이다. 이러한 시스템은 데이터 제공(행동), 반응 감지(보상), 적응의 학습 사이클을 계속 반복됨으로써 전체적으로는 시행착오를 통해서 학습하는 강화학습의 형태를 취하게 된다.

Learnability and Representational Power. 기계학습에서의 근본적인 딜레마 중의 하나는 표현력과 학습력의 균형 문제이다. 즉 학습 모델 구조의 표현력을 증가하면 어떤 복잡한 문제도 원리적으로는 잘 학습할 수 있다. 반면에 표현력이 증가하면 모델 구조의 공간이 커져서 제한된 학습 데이터로부터 올바른 학습 모델을 찾아내는 것은 더욱 어려워진다. 기계학습이 기술적으로 성공한 요인 중의 하나는 대상으로 하는 모델 구조의 탐색 공간의 크기 즉 표현력을 극도로 제한한 다음 이 모델의 계열내에서 탐색함으로써 그 표현력의 범위내에서는 아주 유용한 모델들을 효율적으로 찾아내는데 성공한 것이다. 이는 고전적인 인공지능에서 표현력이 뛰어난 기호적 표현을 사용한 학습 방법들이 실제적 응용에는 실패한 것과 대조적이다. 그러나 이제 많은 문제들이 잘 해결되고 있는 시점에서 다시 표현력을 향상하는 연구가 필요하다. 이러한 시각에서 보면 현재의 커널 머신과 확률 그래프 모델도 기존의 퍼셉트론의 표현력을 증가시키려는 여러 가지 시도 중의 하나로 볼 수 있다. 앞으로는 여기서 한 단계 더 나아가 확률그래프 모델에 ILP의 기호적 표상 능력을 부여하는 것과 같은 새로운 모델들이 연구되어야 할 것이다.

Learning and Evolution. MyLifeBits와 같이 목표 함수가 시간이 감에 따라서 동적으로 변할 수 있는 환

경에서는 단기적인 적응(학습)과 장기적인 생존(진화) 간의 균형이 중요하다. 즉 너무 단기적인 적응에 치중하면 변화하는 환경에서 장기적으로 살아남기 어렵고 그렇다고 단기적인 것을 무시하면 당장의 수행능력에 문제가 생긴다. 특히 앞에서 논의한 표현력과 관련하여, 학습 시스템이 지속되는 동안에 고정된 복잡도의 모델을 사용하는 것이 아니고 변화하는 복잡도의 모델 구조를 사용할 경우 이 문제는 더욱 잘 해결될 수 있다. 단기적으로는 고정된 모델 구조상에서 파라미터 학습에 치중하고 장기적으로는 모델 구조를 진화시키면서 학습하는 이중 학습 전략을 사용하는 것을 생각해 볼 수 있다.

Learnable Matter. 사람이나 동물이 현재의 실리콘 컴퓨터 보다 학습을 더 잘 하는 것은 누구나 부인하기 어려운 사실이다. 그 이유는 여러 가지가 있을 수 있으나 한 가지는 매체의 차이에서 찾을 수 있다. 즉 인간의 뇌에서의 기억과 학습은 현재 분자생물학과 생화학이 밝힌 메카니즘에 의하면 단백질과 같은 분자들의 합성과 축적 및 반응 기작의 변화에 기인한다. 생체내에서의 정보처리 활동은 지금의 디지털 컴퓨터 상에서의 정보처리 활동과는 물리적으로 많이 다르다. 실리콘 보다는 탄소 매체의 물질들이 학습 하는데 더욱 유리하다. 이것은 생명체의 오랜 진화에 기인한다. 따라서 학습 관점에서 유기체의 학습 메카니즘을 자연스럽게 모사할 수 있는 새로운 물질 또는 매체에 대한 연구를 할 필요가 있다.

Learning-Friendly Computational Paradigms. 양보의 원리(The Principle of No Free Lunch)에 의하면 학습(예측력)을 잘 하는 것과 계산(정확도)을 잘 하는 것은 서로 양보해야 하는 관계일 수 있다. 현재의 디지털 계산 기술은 정확도를 추구해 온 반면 기계 학습 기술은 어느 정도의 정확도는 중요하지만 이것이 전부 아니다. 오히려 학습을 잘 하기 위해서는 오류에 의한 새로운 발견이나 망각에 의한 잡음 제거 효과 등의 부정확성이 필요하다. 사람의 정보처리 능력을 모사하는 것이 인공지능의 중요 목표 중의 하나라면 지능적인 시스템을 만들기 위한 기계학습 기술도 사람의 학습과 기억에 관한 이해를 바탕으로 학습이 용이한 새로운 계산 모형을 고안해 볼 수 있을 것이다. 이는 앞의 Learning Matter의 발견과 관련하여 이에 대한 이론적인 모델을 제시하는 연구가 될 것이다. 또한 이러한 계산학적인 학습 연구는 반대로 인간의 학습과 기억 구조 및 기작에 기반한 정보처리 과정 및 지능현상을 더 잘 이해하게 하는 새로운 실마리를 제공해 줄 수 있을 것이다.

6. 결론

기계학습 모델의 전반적인 분류와 특성을 포괄적으로 살펴보았다. 또한 이를 기반으로 앞으로 기계학습 연구가 어느 방향으로 발전될 필요가 있는지도 논의하였다. 많은 논의가 현재의 연구 동향을 분석한 자료에 근거한 것이기는 하나 그 선택에 있어서 저자의 견해가 반영된 것임은 부인할 수 없다. 이 점을 염두에 두고 다시한번 본고의 내용을 정리하자면 다음과 같다.

최근 기계학습 연구는 커널 머신 계열과 확률 그래프 모델 계열에서 특히 활발한데 이들은 그 장단점이 대조적이다. 커널 계열은 변별 모델로서 예측 능력이 우수하나 설명 능력이 부족하고 반면에 확률 그래프 모델은 생성 모델로서 분류 문제에 대한 예측 능력은 좀 부족하나 설명 능력이 뛰어난 특징을 지닌다. 이 두 계열의 모델 모두 기존의 기계학습 모델들에 비하면 표현력을 증가하는 경향이 있으며 이 점에서 귀납적 논리 프로그래밍과 같은 기호적 표현 모델의 표현력을 커널 머신이나 확률 그래프 모델에 접목하려는 시도는 중요한 연구일 것이다.

또한 생성 모델과 변별 모델의 장점을 모두 살릴 수 있는 통합 모델에 대한 연구는 이론적으로 그리고 실제적으로도 아주 중요한 연구 주제일 것으로 보인다. 또한 현재의 성능이 우수한 기계학습 모델들이 기반하고 있는 수치적인 표현 위주의 암묵적 모델 구조와 전통적인 인공지능 분야에서 연구되었던 기계학습 모델이 가지고 있는 이산적인 기호 표현에 의한 명시적인 모델을 통합할 수 있는 기계학습 모델이 연구될 필요가 있을 것이다. 특히 이러한 통합된 학습 모델은 인간의 학습이 현재의 기계학습 모델이 가정하는 것처럼 주어진 학습 데이터 집합에 대해서 고정된 목적 함수를 최적화하는 형태의 정적인 모델보다는 Life-Long Learning 상황과 같이 환경과의 상호작용에 의해서 시간적으로 변할 수 있는 동적인 환경하에서 단기적으로 빠른 적응과 장기적으로 안정된 기억 유지에 의한 생존력을 고려할 때 기계학습이 궁극적으로 해결을 시도해야 할 핵심 문제 중의 하나이다.

비유해 보자면, 물리학에서 만유인력과 양자역학을 모두 설명할 수 있는 통일장 이론 또는 Grand Unified Theory(GUT)를 찾으려 시도하듯이, 실세계 학습 환경을 잘 설명할 수 있는 통합 학습 이론에 대한 연구는 기계학습에 대한 GUT가 있을 것인지 그리고 있다면 어떠한 모양이 될 것인지에 대한 탐구이다. 궁극적인 Grand Unified Theory of Machine Learning에 도달하기 위해서는 Learning-Friendly한 물질과 계산 모형을

찾으려는 시도를 계속하여야 할 것이다. 이를 통해서 기계의 학습 능력과 지능을 향상시키는 기술을 발전시킬 뿐만 아니라 인간의 학습과 인지과정에 대한 이해를 더욱 심화시킬 수 있게 될 것이다.

참고문헌

- [1] Samuel, A.L., Some Studies in Machine Learning Using the Game of Checkers, IBM Journal of Research and Development, 3(3):210-219, July 1959.
- [2] Winston, P.H., Learning Structural Descriptions from Examples. In P. H. Winston(Ed.), The Psychology of Computer Vision, New York: McGraw-Hill, pp. 157-209, 1975.
- [3] Michalski, R.S., J.G. Carbonell, T.M. Mitchell, Machine Learning: An Artificial Intelligence Approach, Tioga Publishing Company, 1983.
- [4] Michalski, R.S., J.G. Carbonell, T.M. Mitchell, Machine Learning: An Artificial Intelligence Approach, Volume II, Morgan Kaufmann, 1986.
- [5] Rumelhart, D.E., J.L., McClelland, and the PDP Research Group, Parallel Distributed Processing-Vols. 1 & 2, MIT Press, 1986.
- [6] Bishop, C., Pattern Recognition and Machine Learning, Springer, 2006.
- [7] Duda, R.O., P.E. Hart and D. G. Stork, Pattern Classification, New York: Wiley, 2001.
- [8] MacKay, D.J.C., Information Theory, Inference, and Learning Algorithms, Cambridge University Press, 2003.
- [9] Mitchell, T., Machine Learning, McGraw Hill, 1997.
- [10] Cowell, R.G., S.L. Lauritzen, and D.J. Spiegelhalter, Probabilistic Networks and Expert Systems, 2005.
- [11] Jordan, M.(Ed.), Learning in Graphical Models, MIT Press, Cambridge, MA, 1998.
- [12] Schoelkopf, B., C.J.C. Burges, and A.J. Smola, Advances in Kernel Methods: Support Vector Learning, MIT Press, Cambridge, MA, 1999.
- [13] Shawe-Taylor, J. and N. Cristianini, Kernel Methods for Pattern Analysis, Cambridge University Press, 2004.
- [14] Gemmel, J., Bell, G., and Lueder, R., My-

LifeBits: Personal Database Everything, Communications of the ACM, 49(1) : 89-95, January 2006.

- [15] Zhang, B.-T., Accelerated Learning by Active Example Selection, International Journal of Neural Systems, 5(1):67- 75, 1994.



장병탁

1986.2: 서울대학교 컴퓨터공학 학사

1988.2: 서울대학교 컴퓨터공학 석사

1992.7: 독일 Bonn 대학교 컴퓨터과학 박사

1992.8~1995.8: 독일국립정보기술연구소(GMD) 연구원

1995.9~1997.2: 건국대학교 컴퓨터공학과 조교수

1997.3~현재: 서울대학교 컴퓨터공학부 교수, 생물 정보학, 뇌과학, 인지과학 협동과정 겸임 교수.

2001.1~현재: 바이오정보기술연구센터(CBIT) 센터장

2002.6~현재: 과학기술부 바이오지능 국가지정연구실 실장

2003.8~2004.8: MIT Computer Science and Artificial Intelligence Laboratory(CSAIL) 방문교수

2005.12~2006.2: Bernstein Center Berlin 과학재단 방문교수

관심분야 : Biointelligence, Probabilistic Models of Learning and Evolution, Molecular/DNA Computation

E-mail : btzhang@snu.ac.kr

제17회 통신정보 합동학술대회(JCCI 2007)

- 일 자 : 2007년 5월 2일~4일
- 장 소 : 휘닉스파크
- 내 용 : 학술발표 등
- 주 최 : 정보통신연구회
- 상세안내 : <http://mobile.ajou.ac.kr/jcci2007>